

部分域适应研究综述*

田青^{1,2,4}, 储奕¹, 孙赫阳¹, 吴一昕¹, 陈松灿^{3,4}

¹(南京信息工程大学 计算机与软件学院, 江苏 南京 210044)

²(教育部数字取证工程研究中心(南京信息工程大学), 江苏 南京 210044)

³(南京航空航天大学 计算机科学与技术学院, 江苏 南京 210016)

⁴(模式分析与机器智能工业和信息化部重点实验室(南京航空航天大学), 江苏 南京 210016)

通信作者: 陈松灿, E-mail: s.chen@nuaa.edu.cn



摘要: 域适应通过将源域知识迁移到任务相似的目标域, 旨在辅助后者更好地学习. 当目标域的数据标签集为源域标签的子集时, 该类场景的域适应称为部分或偏域适应 (partial domain adaptation, PDA). 相比一般的域适应, 尽管 PDA 更具普遍性, 但也更具挑战性, 相关研究较少, 尤其缺少系统的综述. 为此, 旨在弥补这一欠缺, 对现有 PDA 方法进行全面回顾、分析和总结, 为相关社区提供主题研究概貌和参考. 首先针对 PDA 背景、概念和应用领域进行概况总结. 其次, 根据方法的建模特点, PDA 被划分为促进正迁移和抑制负迁移两大类, 进而分别作出回顾和分析. 然后, 对常用的实验基准数据集进行归类 and 总结. 最后, 对现有 PDA 工作存在的问题进行了分析, 并提出了其未来可能的发展方向.

关键词: 域适应; 部分域适应; 促进正迁移; 抑制负迁移

中图法分类号: TP18

中文引用格式: 田青, 储奕, 孙赫阳, 吴一昕, 陈松灿. 部分域适应研究综述. 软件学报, 2023, 34(12): 5597–5613. <http://www.jos.org.cn/1000-9825/6806.htm>

英文引用格式: Tian Q, Chu Y, Sun HY, Wu YX, Chen SC. Survey on Partial Domain Adaptation. Ruan Jian Xue Bao/Journal of Software, 2023, 34(12): 5597–5613 (in Chinese). <http://www.jos.org.cn/1000-9825/6806.htm>

Survey on Partial Domain Adaptation

TIAN Qing^{1,2,4}, CHU Yi¹, SUN He-Yang¹, WU Yi-Xin¹, CHEN Song-Can^{3,4}

¹(School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China)

²(Engineering Research Center of Digital Forensics, Ministry of Education (Nanjing University of Information Science and Technology), Nanjing 210044, China)

³(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

⁴(Key Laboratory of Pattern Analysis and Machine Intelligence, Ministry of Industry and Information Technology (Nanjing University of Aeronautics and Astronautics), Nanjing 210016, China)

Abstract: By transferring the knowledge of the source domain to the target domain with similar tasks, domain adaptation aims to assist the latter to learn better. When the data label set of the target domain is a subset of the source domain labels, the domain adaptation of this type of scenario is called partial domain adaptation (PDA). Compared with general domain adaptation, although PDA is more general, it is more challenging with few related studies, especially with the lack of systematic reviews. To fill this gap, this study conducts a comprehensive review, analysis and summary of existing PDA methods, and provides an overview and reference of subject research for the relevant community. Firstly, an overview of the PDA background, concepts, and application fields is summarized. Secondly, according

* 基金项目: 国家自然科学基金 (62176128); 模式识别国家重点实验室开放课题 (202000007); 中央高校基本科研业务费 (NJ2022028); 江苏省“青蓝工程”优秀青年骨干教师人才计划; 江苏省研究生科研实践创新计划 (KYCX22_1205)
收稿时间: 2022-01-25; 修改时间: 2022-05-19; 采用时间: 2022-09-16; jos 在线出版时间: 2023-04-13
CNKI 网络首发时间: 2023-04-13

to the modeling characteristics, existing PDA methods are divided into two categories: promoting positive transfer and alleviating negative transfer, and this study reviews and analyzes them respectively. Then, the commonly used experimental benchmark datasets are categorized and summarized. Finally, the problems in existing PDA studies are analyzed to point out possible future development directions.

Key words: domain adaptation; partial domain adaptation (PDA); promoting positive transfer; alleviating negative transfer

1 部分域适应研究背景

在传统机器学习中,通常假设训练数据与测试数据具有完全相同的分布.但在现实应用中,这两者之间通常存在着边缘分布^[1]、条件分布^[2,3]等方面的分布差异.以人脸图像数据为例,不同数据集的采集通常在种族、光照、设备等方面存在不同,以致所得数据集之间难免存在分布差异.然而,这种跨数据分布差异将显著降低训练所得估计器在测试数据上的泛化性能.例如,对基于白种人脸训练集所得的年龄分类器,当将其用于非白种人脸时,测试结果通常会显著变差^[4].另外,传统机器学习模型的训练通常依赖大量的数据标注.然而,大规模的标记数据通常较难以获得,这将严重限制传统机器学习方法的泛化能力.为应对以上问题和挑战,借助已有源任务知识辅助目标任务学习的迁移学习范式被提出.在迁移学习中,当源任务和目标任务相同但其数据空间分布不同时,这种场景的迁移学习称为域适应^[5-7].

域适应通过对已有知识的迁移和建模利用,减少了对大规模标注数据的依赖和要求,并在很多领域取得了较好的应用,如计算机视觉^[8-11]、自然语言处理^[12,13]等.其中,现有的域适应方法大多集中于解决计算机视觉任务,例如:目标检测^[9,13-16]、行人重识别^[17-24]、图像生成^[18,25]和语言分割^[26]等方面,同时还包括在医学图像领域中的应用,例如:心脏核磁共振图像、X射线分割^[10]等.除此之外,域适应方法还被应用于自然语言处理问题上,例如文本分类^[27]、词性分类^[28-31]、情绪分析^[12]和数据预测^[13]等方面.虽然现有域适应模型在不同领域得到了较好的应用,但是其主要通过减少域差异且依赖于完全共享标记空间的假设.

从大数据层面对域适应问题进行研究,可以假设大规模数据集的多样性足以覆盖小规模数据集的所有类别,其正符合部分域适应问题场景的设定.随着大数据的普及,部分域适应问题将受到更广泛的关注和研究,即在现实应用中目标域标记空间往往为源域标记空间的子集,而这种特殊的域适应称为部分域适应 (partial domain adaptation, PDA)^[32],其作为一种特殊的域适应同样也被应用到现实生活中^[33,34].部分域适应问题相较于标准的域适应问题更具有普遍性和挑战性,如图 1 所示,在部分域适应中源域存在与目标域无关类的样本,目标域标记空间为源域标记空间子集,其中无关类样本(头盔)会在迁移时产生负迁移.负迁移是指模型在域适应后的其表现甚至比在源域上有监督情况下训练的表现更差,这是部分域适应问题最具挑战性的问题.目前虽已有不少对于部分域适应的研究工作被提出,但并未有对此类场景下域适应方法系统性的分析总结.




图 1 部分域适应问题数据分布情况

具体而言,在部分域适应问题中,给定一个已标记的源域 $D_s = \{\mathbf{x}_i^s, \mathbf{y}_i^s\}_{i=1}^{n_s}$ 和一个未标记的目标域 $D_t = \{\mathbf{x}_j^t\}_{j=1}^{n_t}$, 其中 \mathbf{x}_i^s 、 \mathbf{x}_j^t 分别表示源域和目标域样本, \mathbf{y}_i^s 为源域样本对应的标签, n_s 为源域样本数, n_t 为目标域样本数. 源域的数据分布 $P(\mathbf{x}^s)$ 与目标域分布 $P(\mathbf{x}^t)$ 存在差异, 即 $P(\mathbf{x}^s) \neq P(\mathbf{x}^t)$. 并且目标域标记空间 \mathcal{Y}_t 为源域标记空间 \mathcal{Y}_s 的子集, 即 $\mathcal{Y}_t \subset \mathcal{Y}_s$. 部分域适应的目标是利用有标签的源域数据, 将源域知识迁移到目标域中, 从而使得目标域数据得到准

确的预测分类.

部分域适应作为一种特殊的域适应问题,除了需要抑制负迁移之外,如何促进域适应过程中的正迁移也是解决部分域适应问题的关键.此外,部分域适应问题同样存在目标域拥有不同监督信息的情形,然而,据调查所知,现有方法通常面向无监督下的部分域适应问题展开研究,而半监督场景下的部分域适应问题鲜有相关研究.基于此,本文依据将现有无监督部分域适应方法划分为促进正迁移和抑制负迁移两大类,再根据不同的方法以及其应用的对象,对促进正迁移和抑制负迁移于源域和目标域进一步细分,并对相关代表工作进行回顾和分析.基于上述分析角度,本文将现有部分域适应工作总结并划分为如图2所示.

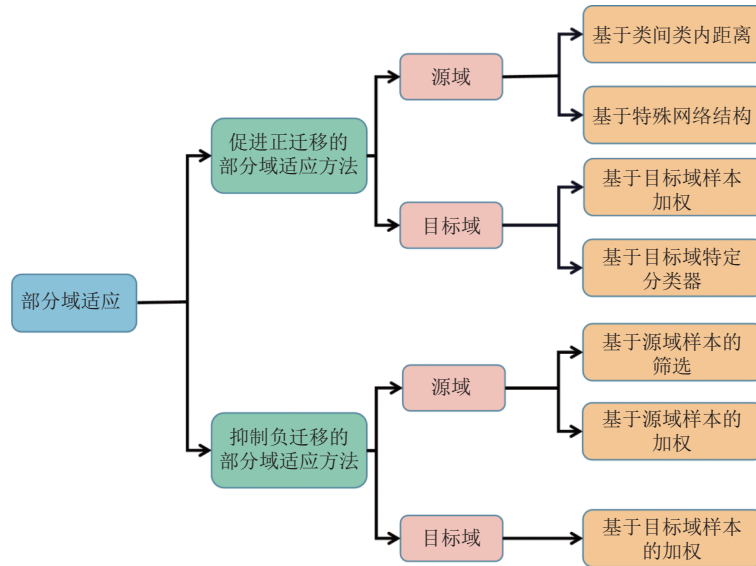


图2 不同部分域适应方法划分

本文第2节介绍和回顾现有基于正迁移建模的部分域适应方法,并进行相关的分析.第3节对负迁移避免建模的部分域适应方法进行回顾和总结.第4节介绍域适应领域研究相关的基准数据集.第5节总结当前部分域适应研究的现状,提出现有工作存在的不足以及未来部分域适应可能的发展方向.第6节对全文工作进行总结.

2 基于正迁移促进的部分域适应方法

2.1 源域中的正迁移促进方法

在域适应问题中,能否有效地消除源域和目标域之间的分布差异是解决问题的关键,而此类从正面促进域适应效果的方式称为促进模型正迁移.为了促进正迁移,现已有大量的研究从不同层面出发提出了各不相同的方式,而部分域适应同样作为域适应问题也受到了大家的广泛研究.因此本文将已有方法根据其不同层面将其分为以下两类,其主要包括按照样本分布的不同,通过度量的方式缩小源域和目标域之间的差异,从而消除两者间的分布差异,以及通过特殊网络结构从特征层面,通过对样本特征更有效地提取来有效地促进正迁移,从而能更好地解决部分域适应问题.

2.1.1 基于度量的部分域适应方法

按照域分布对齐的方式不同,现有的域适应方法大致可分为边缘分布域适应^[35-40]、条件分布域适应^[41-44]和联合分布域适应^[45-49],这些方法大多被应用于促进域适应的正迁移.边缘分布域适应应用源域和目标域边缘分布概率距离衡量两个域之间的差异,如公式(1)所示:

$$Dis_{(D_s, D_t)} \approx \|P(\mathbf{X}_s) - P(\mathbf{X}_t)\|_2^2 \quad (1)$$

其中, $P(\mathbf{X}_s)$ 代表源域样本分布, $P(\mathbf{X}_t)$ 代表目标域样本分布, D_s 和 D_t 分别代表源域和目标域, \mathbf{X}_s 和 \mathbf{X}_t 分别代表源

域和目标域样本.

条件分布域适应是用源域和目标域的条件分布概率来衡量两个域之间的差异,如公式(2)所示:

$$Dis_{C(D_s, D_t)} \approx \|P(\mathbf{Y}_s|\mathbf{X}_s) - P(\mathbf{Y}_t|\mathbf{X}_t)\|_2^2 \quad (2)$$

其中, $P(\mathbf{Y}_s|\mathbf{X}_s)$ 代表源域样本的条件分布, $P(\mathbf{Y}_t|\mathbf{X}_t)$ 代表目标域样本的条件分布.

联合分布域适应同时考虑源域和目标域的边缘分布概率和条件分布概率,以此来衡量两个域之间的差异,如公式(3)所示:

$$Dis_{C(D_s, D_t)} \approx \|P(\mathbf{X}_s) - P(\mathbf{X}_t)\|_2^2 + \|P(\mathbf{Y}_s|\mathbf{X}_s) - P(\mathbf{Y}_t|\mathbf{X}_t)\|_2^2 \quad (3)$$

这3种方法均属于度量在机器学习中的建模手段,同时也是解决域适应问题的常见策略,其通过度量的方式来衡量两个域之间的差异.具体而言,最大均值差异(maximum mean discrepancy, *MMD*)^[50,51]是域适应问题中最常用的度量方式.针对 *MMD* 而言,其为度量在再生希尔伯特空间中两个分布的距离,是一种核学习方法. *MMD* 被广泛地应用在深度域适应方法中,如公式(4)所示:

$$MMD^2(\mathbf{X}, \mathbf{Y}) = \left\| \sum_{i=1}^{n_1} \Phi(\mathbf{x}_i) - \sum_{j=1}^{n_2} \Phi(\mathbf{y}_j) \right\|_H^2 \quad (4)$$

其中, $\Phi(\cdot)$ 代表特征空间映射.

鉴于 *MMD* 方法能够有效地解决了域适应问题,因此该方法同样也可应用于部分域适应方法,并已有相关研究将其有效地利用.

Jing 等人^[52]提出了一个跨域中心损失来寻找域不变特征空间,其中未标记的目标样本往往以概率重构格式与不同的源类中心耦合,通过度量源域和目标域的边缘概率分布和条件概率分布来优化重构系数.为了最小化边缘分布,该工作利用 *MMD* 方法对此问题进行了解决.针对条件分布,现有的域适应方法^[53-55]通过利用伪标签来对齐条件分布,然而其大多假设域适应在两个域中对齐每个类别.在部分域适应中,由于存在不相关的源域类,如果对源域和目标域整体进行条件分布的对齐,将不能够获得较好的域适应效果.因此该工作通过度量的方式计算出源域样本于目标域样本的相似度,从而构建重构系数,来最小化两个域的条件分布差异.除了上述建模策略,该工作为了进一步最小化不同域间同一类别的分布差异,同样通过度量的方式利用聚类的思想构建目标函数,使得同一类别的样本间的距离减小.

Li 等人^[56]认为在现有部分域适应的工作所用策略大多涉及源域和目标域之间的域对齐,但域间差异的限制以及部分域适应问题的特殊场景导致了其不能实现较为完善的域对齐,从而在域适应过程中产生较大的风险.因此该工作提出了一种新的泛化误差界从模型平滑性的角度来解决部分域适应问题,此外其利用对源域真实标签和分类器所得标签的度量来计算源域上的经验损失,以训练分类器.除了上述度量方式外,该工作通过对样本间进行余弦距离的计算以实现样本间的相似度度量,并构建拉普拉斯正则化项,以此在保持域内结构的同时减少源域不相关类样本在域适应过程中所造成的负迁移.

上述方法主要集中致力于源域和目标域间的边缘分布差异,但为了进一步提升迁移效果促进正迁移, Kheirandishfard 等人^[57]针对条件分布提出了一种新的对抗性架构,其结合两种新的正则化函数来提高目标域的分类性能.第1个正则化器是分类器输出上的一个行稀疏性项,以促进源域和目标域之间共同的小子集类的选择.第2个是一个最小熵项,它增加了分类器从两个域预测无关样本标签的置信水平,进一步促进了正迁移.

2.1.2 基于特殊结构的部分域适应方法

近年来,自注意机制在广泛的任务中得到了显著的进展,例如对象识别^[58,59]、姿态估计^[60-62]、机器翻译^[63,64]和图像字幕^[65,66],尽管它在各种计算机视觉和机器学习方面取得了成功,但自注意力机制在域适应领域中仍未被较好地利用.注意力机制类似于视觉系统倾向于关注图像中辅助判断的部分信息,并忽略掉不相关的信息,这与域适应问题存在共通,因此可以通过应用注意力机制,以达到促进域适应中的正迁移的目的.

Zhang 等人^[67]将非局部自注意机制嵌入到深度局部域自适应模型中,以学习细粒度特征来提高模型的性能,达到促进正迁移的目的.该工作从给定的特征提取器提取特征,分别提取出两个特征,将其维度重塑后,通过

Softmax 运算计算出自注意力图,其自注意力框架如图 3 所示.然后利用所得到的自注意力图对特征进行加权,以有效地得到域不变特征.随着不断地训练,在自注意力机制下相对于整体更重要的特征,即域不变特征将分配更多的权重,以实现部分域适应.除了自注意力机制的应用,该论文还通过运用现有较为经典的部分域适应模型^[68],并将两者有效地结合,通过大量的对比实验证明了其有效性.

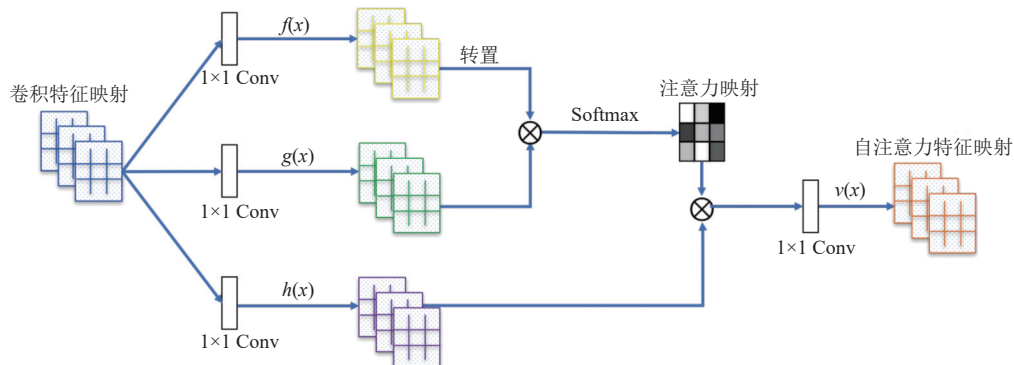


图 3 自注意力框架在部分域适应问题上的应用^[59]

除了注意力机制外,图结构^[69-72]作为加权的一种方式同样被应用到域适应问题中,其结构如图 4 所示.为了得到红色节点的隐藏表示,图卷积运算的一个简单解是取左侧中心节点特征及其邻居的平均值.与图像数据不同,节点的邻居是无序的,大小是可变的.图像可以看作是图中像素由相邻像素连接的图的一种特殊情况.与二维卷积类似,可以通过取节点邻域信息的加权平均值来进行图卷积.对于图来说,图中的每个数据样本(节点)都会有边与图中其他数据样本(节点)相关,这些信息可用于捕获实例之间的相互依赖关系,也正是因为这一原因,图结构网络能够在部分域适应问题中取得较好的表现.




图 4 图卷积结构应用示意图

Kim 等人^[73]认为当基于图的方法处理非结构化输入时,定义节点和边是最重要的问题,其将每个样本视为一个节点,并基于类信息提出了两种类型的新边.第 1 种是每个样本的类标签之间的相似性定义的关系边,即源域的真实标签以及由分类器预测的软标签.考虑到初始的预测标签置信度较低,该工作提出了第 2 种新边,其为自适应的二进制边,通过逐步的训练而提升标签预测的可靠性.其将两种类型的边结合利用域内和域间结构中的自信关系构建整体模型,并通过应用对抗机制有效地解决了部分域适应问题.

图卷积网络(graph convolutional network, GCN)^[74,75]最近因其计算效率和可伸缩性而广受欢迎.与传统的只对网格输入^[76]进行操作的卷积操作不同,GCN 只在边缘连接的节点之间执行连续的传播.将 GCN 应用于非图数据时的关键问题是定义节点之间的连通性,即节点间的边.PDA 问题也与为传统域适应而设计的图卷积对抗网络(graph convolutional adversarial network, GCAN)^[77]有关.为揭示域内和域间的关系, Yang 等人^[78,79]将图卷积对抗网络应用于解决部分域适应问题,其根据样本类标签的相似性来定义自适应边,以此来有效地减少负迁移所带来的影响.

除了上述两种特殊结构,加权策略作为部分域适应中最为常见的方法,其性质与强化学习中的奖励机制类似,

因为强化学习也被应用于部分域适应问题,并取得了较好的表现.现有工作大多直接将强化学习网络直接应用到部分域适应中,通过奖励机制对相关类给予较大奖励权重,以此来促进正迁移^[80,81].

2.2 目标域中的正迁移促进方法

除了从源域层面来促进模型正迁移,同样也有部分工作针对如何利用目标域信息来更好地实现域适应.对于无监督域适应问题,由于目标域样本无监督,现有研究往往利用源域预训练的分类器,对目标域样本进行分类,使其获得相应的伪标签,而又因存在低置信度的伪标签,通常无法有效地在目标域上利用其条件分布来促进模型的正迁移,因此如何有效利用目标域样本的不同置信度的伪标签是解决部分域适应问题的关键.本文根据针对目标域样本监督信息不同利用方式,将现有部分域适应研究分为以下两类,并对其展开回顾以及相应的分析.

2.2.1 基于目标域样本加权的部分域适应方法

除了从源域层面来促进正迁移,同样也有部分工作针对如何利用目标域来更好地实现域适应展开研究.对目标域样本加权大多是在对源域样本加权的基础上,通过计算目标域样本的置信度来对其进行加权,旨在利用类别级别的权重在部分域适应场景下,提高对齐的效果及增加相关类的重要性,由此来促进正迁移以提高模型的表现.

Li 等人^[82]正是利用这种加权策略构建了双重对齐部分域适应模型,并通过实验证明了其有效性.其所提模型共有 3 个部分组成,分别为用孪生网络所构建的特征提取器,重加权网络以及双重对齐网络,首先通过共享参数的孪生网络构建特征提取器,由此来提取出样本的域不变特征,以更好地进行迁移学习.然后利用其构建的重加权网络,首先通过分类器对源域和目标域样本进行分类,分别得出分类损失以及目标域的概率标签,再由所得概率标签对源域和目标域样本进行加权.由此通过对目标域样本进行加权,以达到在使相关类的样本具有较大的权重,以及促进相关类正迁移的目的.对于目标域样本的加权是对其置信度的衡量,权重值越大说明其概率标签越有可能是真实的.此外关于对目标域的加权,该工作认为如果每个目标样本用硬标签进行标记,并用一个常数(即 1)加权,则可能会产生错误对齐问题,因为重加权网络可能会由于较大的域偏移而错误地预测某些样本.特别是当目标域样本位于两个类分布的重叠区域时,给这些样本分配硬标签并用常数加权会破坏目标域数据结构.除了上述两种网络结构之外,该文章还提出了双重对齐网络,利用缩小类内距和扩大类间距的方式对样本进行对齐,此外还利用扩大域间距的方式来完善所用对齐方式,由此来优化类间损失以及类内损失.

总体而言,该工作所用方法相对于对源域加权策略更加全面,能够合理地通过对目标域样本的加权来提高促进正迁移,特别是在对于处于分类边界的目标域样本的分类任务上有显著的作用.但是同样通过对这篇文章的回顾,在部分域适应中,仅对目标域或者源域进行加权是不够全面的,两者同时采取不同的加权策略可以显著地降低在迁移时的分类误差.

2.2.2 基于目标域特定分类器的部分域适应方法

同样是通过目标域样本伪标签的利用来促进域适应的正迁移, Ren 等人^[83]提出 PEAL 方法,通过一种目标域特定的分类器来解决域漂移问题,其主要目的是通过学习一个置信度更高的分类器来提高模型的判别性,促进模型的正迁移.该方法利用公共分类器对目标域样本进行分类并获得伪标签,然后通过设置概率标签阈值,并与所获得伪标签比较,筛选出置信度较高的标签及对应的样本,将目标域划分为两个部分,一部分将继续保留获得的伪标签,另一部分作为无标签的目标域样本.其次利用获得伪标签的目标域样本通过交叉熵损失训练新的分类器,作为目标域的分类器对剩余目标域样本进行分类.除此之外,考虑到新建的分类器仅在已有标签的目标域上训练会导致过拟合现象,从而导致其余目标域样本被错误分类,该工作另外增加了辅助分类器对目标域分类器进行决策边界的适应性调整,从而提升目标域分类器的分类精度.通过设立的目标域分类器和辅助分类器组成了目标域所特定的分类器组合,由此从目标域的层面促进了模型的正迁移.

该方法主要通过对分类边界的调整提高目标域样本的分类精度,以提高目标域样本伪标签的置信度来从目标域层面出发促进了模型的正迁移.

3 基于负迁移抑制的部分域适应方法

与域适应中的正迁移相反,负迁移在部分域适应过程中是指源域冗余知识对整体模型的迁移效果所造成的负

面影响. 在部分域适应场景中如何解决源域中所包含的不相关类所造成的负迁移是部分域适应问题的核心研究内容, 因此抑制负迁移作为解决部分域适应的常见方法, 被广泛研究并有许多相关的工作被提出. 本文根据抑制负迁移方法的应用, 根据其应用于源域和目标域的不同方式, 本文从这两个层面对基于抑制负迁移的部分域适应工作进行分类和回顾分析.

3.1 源域中的负迁移抑制方法

在部分域适应中, 如何处理源域中的无关类样本造成的负迁移是解决部分域适应问题的关键, 本文针对现有方法对源域样本的不同处理方式, 将现有通过抑制源域所产生负迁移的部分域适应研究分为以下两类, 并对其进行了回顾及分析.

3.1.1 基于源域样本筛选的域适应方法

部分域适应问题相较于一般域适应问题, 最大的差异在于源域标记空间与目标域标记空间之间的关系, 而源域中冗余的不相关类所对应的样本如果不进行处理, 在域适应的过程中通过模型的不训练, 会将不相关类的知识应用到目标域样本的分类中, 从而导致分类精度的下降, 对模型造成较大的负面影响. 在此场景下, 其中最直接且有效的方法是利用不同策略对源域样本进行筛选, 将不相关和相关类的样本区分开, 再利用相关类样本进行模型的训练, 将部分域适应尽可能地转换为闭集域适应, 从而使得模型在部分域适应场景下达到较好表现, 其主要思路如图 5 所示.

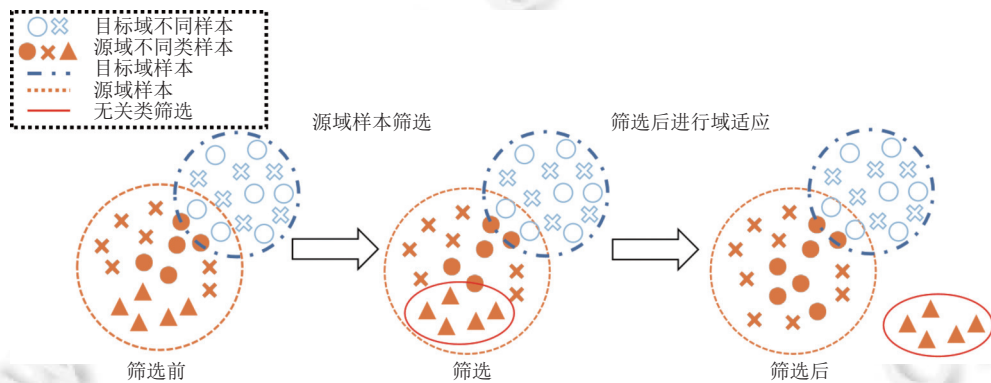


图 5 部分域适应中源域样本筛选的主要思路

Jing 等人^[84]提出了一种自适应累积的知识转移策略, 在源域数据的指导下迭代地加权和过滤出置信度较高且相关的目标样本及其相应的类别, 以实现有效地跨域对齐. 其次, 探讨了两种不同类型的任务特定分类器, 从不同的角度捕捉和传递跨域的内在分布知识. 然后提出了一种跨域对齐损失函数, 该函数能够跨域实现样本类别级别的对齐及判别, 并压缩同一类内的样本级分布. 与前述工作想法类似, Wang 等人^[85]针对无关源域样本的筛选, 应用局部保留投影算法 (locality preserving projections, LPP) 以及标记传播^[86]等方法, 有效地缩小了负迁移所带来的影响. 目前大多数工作^[87-89]对目标域样本仍采用利用伪标签的相关策略, 以缩小源域和目标域条件概率分布, 但是在部分域适应的背景下这种方式是不可靠的, 因此该工作为解决这类问题提出了自适应的样本筛选策略, 由此来筛选出源域内的无关类样本. 即只有样本的置信度达到所提置信度阈值的样本才能进行跨域对齐.

Choudhuri 等人^[90]同样通过对源域样本进行筛选, 选出相关类所对应的样本完成部分域适应. 其首先通过分类器对源域样本进行分类获得对应的概率标签. 然后设置概率阈值, 与各样本所对应的概率标签进行比较, 将概率标签转化为二分类的标签, 作为判断该类样本是否与目标域样本相关, 并且通过度量不同聚类中的方差动态地更新概率阈值, 从而使得阈值逐渐增大即不相关类与相关类的错误分类概率越小. 由此将软标签转化为二值标签, 实现对源域样本的筛选, 再利用筛选出的源域样本与目标域样本进行解码重构, 最后利用相关的源域和目标域样本进行域适应任务.

Sahoo 等人^[91]将源域样本筛选作为构建模型的组成模块, 以此来消除不相关类所造成负迁移, 该工作计划

通过构建样本筛选模型, 筛选出源域不相关类, 并根据相关与否使源域样本获得二值分类标签, 考虑到离散决策策略使得网络不可微, 从而无法反向传播, 因此其利用 Gumbel-Softmax 分布作为连续松弛, 并通过比较源域样本的概率标签与所得 Gumbel 分布结果, 对源域样本进行筛选, 区分出相关与不相关类, 除此之外该工作通过应用样本混合的方式来消除筛选出异常类后所产生的过拟合现象, 以此来更好地消除不相关类所造成的负迁移。

除了上述筛选出不相关源域样本后, 仅用相关样本进行训练的方式外, 还有一种特殊的方式, 该类方法通过筛选源域样本或者利用自监督方式将源域样本^[92]作为目标域样本的补充, 以此来解决源域和目标域标记空间不匹配的问题. Liang 等人^[93]针对部分域适应问题, 提出了 BA³US (<https://github.com/tim-learn/BA3US>) 方法, 考虑到源域与目标域拥有不同的标记空间, 因此为了匹配两者的标记空间, 其通过平衡对齐标记空间的方式, 增加目标域标记空间. 其主要通过随机筛选出源域样本, 并将所筛选出来的样本作为目标域样本进行模型的训练, 以此来弥补目标域标记空间的不完整. 随着不断地迭代对抗性学习, 从源域用筛选出的样本数量逐渐减少, 而目标域逐渐与源域相似, 从而将因存在不同标记空间而具有挑战性的部分域适应问题转化为已有大量研究工作的一般场景下的无监督域适应问题. 除此之外该工作在筛选源域样本的同时利用自适应加权补熵来提高伪标签的置信度, 以此更好地解决部分域适应问题. 但该工作采取随机筛选源域样本的方式, 其时间复杂度较高, 且不能够很好地保持源域信息具有很大的随机性. 而 Huang 等人^[68]同样通过对补充目标域标记空的方式来解决部分域适应问题中的关键性问题, 与前者不同的是, 其通过筛选出源域中具有代表性的样本以此来更好地维持域不变特征. 该工作通过设置动态概率标签阈值, 并利用预训练的源域分类器对源域样本进行分类, 得到其概率标签并与阈值进行比较, 筛选出概率标签大于阈值的源域样本作为目标域样本的补充, 以此来更好地解决两者标记空间不一致的问题。

3.1.2 基于源域样本加权的域适应方法

如前文所述, 对源域样本的筛选固然可以解决部分域适应中标记空间不匹配的问题, 但仅考虑到不相关类对域适应效果的负迁移是不全面的. 在对源域样本进行筛选的过程中, 由于对样本分类的不确定性, 可能会将相关样本错误划分为不相关样本, 从而在域适应的过程忽略该样本所蕴含的源域信息, 使得域适应效果有所降低. 因此, 为解决这种问题, 在基于源域样本筛选思想的基础上, 对源域样本进行加权的相关方法得到了广泛的研究. 此类针对源域样本加权的方法是当前部分域适应问题领域最为常见的方法且得到了广泛的应用. 相较于对源域样本筛选, 此类方法能够更加有效地保持源域信息, 实现更好的部分域适应效果。

Cao 等人^[32,94]对部分域适应问题有较为深刻的理解, 并提出了多种解决部分域适应问题的方法, 从不同角度对该问题进行解决, 其中着重在于对于利用源域样本的加权抑制部分域适应问题中的负迁移现象, 来提高整体域适应效果。

Cao 等人^[32]首次提出部分迁移学习的概念, 并在后续的研究中演化为部分域适应. 该工作基于生成对抗网络的思想, 针对部分域适应问题中的关键性问题对网络结构进行了改进提出了 SAN 网络 (<https://github.com/thuml/SAN>), 其具体模型架构如图 6 所示。

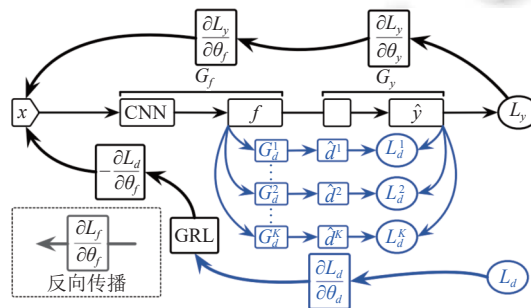


图 6 SAN 模型架构图

所提 SAN 网络通过设置数量等同于源域类数目的域判别器 G_d^k , 并按照样本所属类别分别进行训练, 再利用所得分类器对样本进行分类得到其概率标签 \hat{y} 对域判别器损失进行加权, 从而抑制域适应过程中的负迁移, 除此

之外引用条件熵增加分类器所得伪标签的置信度。

在前文所提工作的基础上, Cao 等人^[94]对模型框架进行了更改,他们认为仅对域判别器利用概率标签加权是不全面的,且多个域判别器所造成的累计损失误差较大,不利于有效地提高域适应效果。因此在 Cao 等人^[94]通过对共享的域判别器以及共享的分类器利用概率标签加权,来有效地解决部分域适应问题中源域和目标域标记空间不一致的问题,消除模型在域适应过程造成的负迁移。该方法基于 DANN^[95]的基本思想构建模型,提出了部分域适应中最为典型的网络结构 PADA (<https://github.com/thuml/PADA>),其作为目前部分域适应领域中最为广泛应用的方法,并作为解决部分域适应问题的基准被广泛进行对比,同时作为利用对源域样本加权方式在部分域适应场景中取得较好效果的最典型性方法被研究者们广泛研究,并在此方法的基础上不断深入研究拓展。除了前两种方法外, Cao 等人^[96]认为利用概率标签作为分类器以及域判别器的权重是不全面的,其并不能较好地诠释源域样本和目标域样本的相似性,因此提出了 ETN (example transfer network) 方法 (<https://github.com/thuml/ETN>),利用两者的相似性通过权重的方式来评估样本的可迁移性,用来衡量不同样本对源域分类器和域判别器的贡献。相较于之前的工作,该方法提出了一种权重计算的方式,进一步扩展了权重所涵盖的意义,利用此方式能够更好地检测和过滤不相关的源域样本,将源域样本和目标域样本通过对抗网络限制在共享的标记空间中,从而在促进正迁移的情况下,极大地抑制了负迁移。

受到 Cao 等人^[32]工作的启发,许多相关的工作^[97,98]被提出。Zhang 等人^[97]提出了一种利用双域判别器对样本进行识别,比通过所得结果对源域样本进行加权以解决部分域适应问题,其认为若第 1 个域判别器能够有效地区分源域和目标域,那所筛选出的样本很可能是来自源域中的无关样本,即样本的邻域区域覆盖了很少或根本没有目标域样本,并为样本分配了一个较小的权重,然后再利用第 2 个域判别器对特征提取器进行对应的优化。同样是对源域样本进行加权, Qiu 等人^[99]在 PADA 的基础上,认为从样本层面对源域样本进行加权是不全面的,目标域样本对不相关类样本几乎没有相关性,随着训练次数的不断增加,目标域样本通过对应分类器所得概率标签会变得足够小,因此其提出了利用多个分类器对目标域样本分类,并通过所得概率标签构建权重机制,对源域样本进行加权,以此来减轻源域中不相关类所引起的负迁移。Hu 等人^[100]基于 OTSU 算法对源域样本进行了划分,由此来获得共享类的标签,然后再利用所获得的标签降低离群类的权重,增加共享类的权重。同时该工作还提出了一种网络架构,利用共享样本分类器进行共享样本权重训练,以区分离群样本,实现部分域适应。此外, Yang 等人^[101]通过利用对比学习增强目标域样本的判别性,并对增广样本通过相似度度量获取其相应伪标签,再通过利用其伪标签对源域样本进行加权,从而减轻负迁移对域适应带来的负面影响。

作为解决部分域适应问题的主流方法,针对利用源域样本加权策略来消除不相关类样本所产生的负迁移的相关工作已被大量的提出,同时该方式也作为公认且最有效的方法被广泛引用到不同的部分域适应问题研究中。

3.2 目标域中的负迁移抑制方法

针对应用到目标域上的抑制负迁移方法主要集中于对目标域样本的加权,其大多是在对源域样本加权的基础上,通过计算目标域样本的置信度来对其进行加权,旨在利用类级别的权重来提高对齐的效果以提高模型的表现。以此来减少源域无关类样本在进行条件分布对齐时所造成的错误配对,所导致的负迁移。

Matsuura 等人^[102]认为目标样本和任务特定的决策边界之间的关系对于提取区分特征是较为关键的,因此其利用目标域的分类信息来更有效地提取出具有判别性的特征。该工作提出了一种减少不一致性的双加权网络,其主要通过两个不共享参数的分类网络,利用目标域样本通过所提网络所产生的输出对分类误差进行加权,从而更有效地估计出目标域的标签分布。此外该加权策略通过作用于目标域,并使加权后的分类器对域散度进行度量,进而提取出具有判别性的特征,以更有效地解决部分域适应问题。

由于目标域样本在部分域适应场景下,其所产生的负迁移相较于源域不相关类样本所造成的负迁移对模型的迁移效果影响较小,因此在此方式下的相关工作相对较少,但部分域适应作为特殊的域适应场景,抑制目标域样本所产生的负迁移同样不可缺少。在考虑到源域不相关类样本的情况下,其应作为进一步提升部分域适应效果的关键性策略被深入研究。

4 相关数据集和实验结果

本文对部分域适应研究领域常用的实验数据集进行归纳和整理, 其主要包括 6 种在部分域适应问题中被广泛使用的数据集, 分别为 Office-31^[103]、Office+Caltech-10^[104]、MNIST+USPS^[105]、SVHN^[106]、Office Home^[107]以及 ImageCLEF^[108], 每个数据集都包含至少两个不同的域. 对于这些数据集上的测试, 通常比较不同方法对于目标数据的分类精度, 来对比其不同的性能. 由于各方法对于实验设置有所区别, 尤其是在针对源域和目标域无关类的选取有较大的差异, 因此本文对在不同数据集下的实验结果不做赘述.

4.1 Office-31

Office-31 是一个视觉域适应数据集, 它包括来自 3 个不同领域的 31 类样本, 包含 3 个不同场景的数据集, Amazon (A)、Webcam (W) 和 Dslr (D). Amazon 由在线电子商务图片组成, Dslr 包含高分辨率的图片以及 Webcam 包含由网络相机拍摄的低分辨率照片. 共有 4 652 幅图像, 分别包含来自 3 个域的 2 817、498 和 795 幅图像. 在模型评价中, 正常测试 6 种源域和目标域的组合, 分别为 A→D, A→W, D→A, D→W, W→A 以及 W→D.

4.2 Office+Caltech-10

这个数据集包含 4 个域, 其中 3 个域 (A、D、W) 来自 Office-31, 另一个域 (C) 来自 Caltech-256, 该数据集包含 256 类对象识别的 30 607 张图像. 选择 Office-31 和 Caltech-256 中共有的 10 个类形成该数据集, 因此其分别收集了 A、D、W、C 这 4 个域中的 958、157、295 和 1 123 幅图像, 组成的总共 2 533 幅图像. 在模型评价中, 正常测试 12 种源域和目标域的组合, 分别为 A→D, A→C, A→W, C→A, C→D, C→W, D→A, D→C, D→W, W→A, W→C 以及 W→D.

4.3 MNIST+USPS

MNIST 和 USPS 是两个数据集, 包含 10 种不同分布下的数字图像进行手写数字识别. MNIST 包括 6 万张训练图片和 1 万张测试图片. USPS 包括 7 291 张训练图片和 2 007 张测试图片. 对于域适应任务, 分别从 MNIST 和 USPS 中随机选择 2 000 张图片和 1 800 张图片. 为了提取特征, 将每幅图像的大小调整为 16×16, 最终提取一个编码像素值的 256 维特征向量. 在评估中, 解决了两个域适应任务, 即 MNIST→USPS 和 USPS→MNIST.

4.4 SVHN

SVHN 是一个真实世界的图像数据集, 用于开发机器学习和目标识别算法, 对数据预处理和格式要求较低. 在风格上与 MNIST 相似, 但 SVHN 数据集包含了一个数量级的标记数据 (超过 60 万数字图像), 并且 SVHN 数据集是来自现实世界的数据集 (在自然场景图像中识别数字和数字).

4.5 OfficeHome

OfficeHome 是一个相对较新的数据集, 其包含 65 个类别的 15 585 张图像, 来自 4 个不同的域, 其中包括 (1) Art (Ar): 以素描、绘画、装饰等形式对物体的艺术描述. (2) Clipart (Cl): 剪接图像的收集. (3) Product (Pr): 没有背景的对象图像, 类似于 Office 数据集中的 Amazon 类别. (4) Real-Word (Rw): 用常规照相机捕捉到的物体的图像. 具体来说其分别包含 2 421、4 379、4 428 和 4 357 张图像. 因此共有 12 个域适应任务, 其中包括 Ar→Cl, Ar→Pr, Ar→Rw, Cl→Ar, Cl→Pr, Cl→Rw, Pr→Ar, Pr→Cl, Pr→Rw, Rw→Ar, Rw→Cl 和 Rw→Pr.

4.6 ImageCLEF

ImageCLEF 数据集包括 12 个类别的 1 800 张图像, 它们来自 3 个域: 600 张图片来自 Caltech256 (C), 600 张图片来自 ImageNet ILSVRC2012 (I), 以及来自 Pascal VOC2012 (P) 的 600 张图片. 因此总共有 6 个域适应任务, 其中包括 C→I, C→P, I→C, I→P, P→C 和 P→I.

4.7 部分数据集实验结果

本节在 Office-31 数据集和 OfficeHome 数据集上对现有具有代表性的部分域适应方法的性能进行比较, 其中实验结果均使用预训练过的 ResNet50 作为特征提取器, 所有算法的参数都设置为默认值或者原论文所提供的推

荐值. 表 1 为代表性部分域适应方法在 Office-31 数据集上的实验结果; 表 2 为各方法在 OfficeHome 数据集上的实验结果.

表 1 在 Office-31 数据集上各部分域适应方法的准确率 (%)

方法	A→W	D→W	W→D	A→D	D→A	W→A	平均
SAN ^[32]	93.90	99.32	99.36	94.27	94.15	88.73	94.96
PADA ^[94]	86.54	99.32	100.0	82.17	92.69	95.41	92.69
IWAN ^[97]	89.15	90.32	99.36	90.45	95.62	94.26	94.69
ETN ^[96]	94.52	100.0	100.0	95.03	96.21	94.64	96.73
TWIN ^[102]	86.00	99.30	100.0	86.80	94.70	94.50	93.60
DARL ^[81]	90.17	99.32	100.0	90.45	93.42	93.11	94.41
DRCN ^[109]	90.80	100.0	100.0	94.30	95.20	94.80	95.85
A ² KT ^[84]	97.28	100.0	100.0	96.79	96.13	96.14	97.72
APDA ^[73]	96.61	100.0	100.0	96.17	95.50	95.40	97.28
GPDA ^[78]	96.95	100.0	100.0	98.73	95.10	95.83	97.77
AGAN ^[79]	97.28	100.0	100.0	94.26	95.72	95.72	97.16
CCPDA ^[44]	99.66	100.0	100.0	97.45	95.72	95.71	98.09
BA ³ US ^[93]	98.98	100.0	100.0	99.36	94.82	94.99	97.81

表 2 在 OfficeHome 数据集上各部分域适应方法的准确率 (%)

方法	Ar→Cl	Ar→Pr	Ar→Rw	Cl→Ar	Cl→Pr	Cl→Rw	Pr→Ar	Pr→Cl	Pr→Rw	Rw→Ar	Rw→Cl	Rw→Pr	平均
SAN ^[32]	44.42	68.68	74.60	67.49	64.99	77.80	59.78	44.72	80.07	72.18	50.21	78.66	65.30
PADA ^[94]	51.95	67.00	78.74	52.16	53.78	59.03	52.61	43.22	78.79	73.73	56.60	77.09	62.06
IWAN ^[97]	53.94	54.45	78.12	61.31	47.95	63.32	54.17	52.02	81.28	76.46	56.75	82.90	63.56
ETN ^[96]	59.24	77.03	79.54	62.92	65.73	75.01	68.29	53.37	84.37	75.72	57.66	84.54	70.45
DRCN ^[109]	54.00	76.40	83.00	62.10	64.50	71.00	70.80	49.80	80.50	77.50	59.10	79.90	69.05
A ² KT ^[84]	62.54	83.92	86.69	65.44	74.96	75.04	67.40	55.14	84.37	73.25	60.51	84.09	72.78
APDA ^[73]	54.39	77.98	85.26	73.92	71.60	82.72	69.61	50.87	81.83	78.15	55.70	82.58	72.05
AGAN ^[79]	56.36	77.25	85.09	74.20	73.84	81.12	70.80	51.52	84.54	78.97	56.78	83.42	72.82
CCPDA ^[44]	55.31	80.11	88.07	73.28	71.21	77.63	71.89	52.97	81.41	81.81	56.21	85.15	72.92
BA ³ US ^[93]	51.20	71.70	76.30	64.20	69.90	71.90	63.70	51.40	77.10	70.90	57.10	81.50	68.70

5 当前问题以及未来研究方向

总体而言, 虽然域适应在迁移学习中逐渐引起了人们的广泛关注, 并逐渐成为现在的研究热点, 但部分域适应作为域适应中较为新颖的场景, 目前部分域适应相关工作还为之甚少, 有极大的发展和提升空间. 由于目前部分域适应的现有工作基本仍停留在所总结的几种方法, 但是作为域适应中的特殊场景, 现有相对完善的域适应方法并未在部分域适应场景得以应用. 现有部分域适应方法大多通常基于所获得的目标域伪标签通过对样本加权或筛选实现域适应. 然而, 由于伪标签置信度不定, 其会影响到模型的稳定性. 此外, 现有部分域适应工作通常并未同时考虑正迁移促进和负迁移抑制两个方面, 而仅关注其中一个, 以致相应的方法存在局限性, 仍有较大的提升空间. 除了上述问题外, 在域适应中还存在不同场景, 现有研究仅集中于无监督场景下的部分域适应问题, 而半监督下的部分域适应问题却鲜有研究. 此外, 在域适应中还存在如多源域适应等不同应用场景, 且部分域适应尚未在这些场景中应用. 因此本文认为此类不同场景下的部分域适应问题将成为未来研究的一个重点.

5.1 多源部分域适应问题

在实际应用中, 很难确认数据采集过程中的标签集合域配置, 因此单一的训练集不能满足实际的需求, 所能提

供的源域信息较少,不能达到较理想的域适应效果.近年来,多源域适应由于其能够提供比单源域适应更丰富的信息而受到越来越多的关注,但是其应用场景几乎均为传统标记空间下的域适应问题,在部分域适应问题中并没有与多源域场景相结合,也鲜有相关的工作被提出.针对多源域适应问题,若目标域标记空间均为各个源域标记空间子集,此类场景符合部分域适应场景,且更贴合实际情况.与单源域适应问题不同,多源域适应问题利用多个富含信息的源域往往能够取得更好的迁移效果,但同时多个源域也意味着更多负迁移的产生,这将会是多源部分域适应问题的最需要解决的问题,且此类问题也将成为部分域适应领域的研究热点.

5.2 多目标部分域适应问题

随着多源域适应问题广泛受到人们的关注,与之相关的工作也层出不穷,但同时问题也随之而来,虽然多个监督下的源域能够通过更多的监督信息探索与目标域相关的多个源域之间的标签,提高域适应效果,但是其需要来自多个源域的标签信息,这往往所需成本较高,因此为了解决这个问题,人们提出同时适应多个无监督的目标域以避免获取多个源域的标签信息,多目标域适应的概念被提出.相较于多源域适应,其主要通过探究多个目标域之间所存在的潜在关系,以此使得源域和目标域更好地关联.多目标域适应作为目前的研究热点仅有少数工作被提出,但并没有在部分域适应问题得到很好的应用,而相较于一般的部分域适应问题,多目标部分域适应问题最需解决的问题在于针对不造成过多负迁移的情况下如何促进正迁移.本文认为此类场景同样与部分域适应相贴合,并且也将成为部分域适应问题中亟需解决的问题.

5.3 无源部分域适应问题

与上述两种场景不同,无源域适应是随着信息安全逐步受到人们的重视而衍生出的一种特殊场景^[10],主要体现在是否能够访问到源域数据,在这类场景中已有部分工作被研究,其大多仅利用源域预训练的模型来保证源域信息的有效利用,以此在目标域上取得较好的分类精确度.与此同时部分域适应问题作为域适应中的一种特殊场景,也同样存在此类问题,跟多源部分域适应问题相同,其亟需解决的问题是如何有效地消除负迁移所产生的影响.由于目前即使是无源场景下的传统域适应问题仍存在较大的研究空间,部分域适应问题也将作为无源场景下的一大重要挑战.

6 总 结

域适应是近年来备受关注的迁移自适应学习中的一个新研究领域,其旨在从源域学习领域自适应表示和分类器,从不同但语义相关的目标域表示和识别样本.而部分域适应问题作为特殊的域适应其目的与之相同,不同的是部分域适应的应用场景不同,具体体现在源域标记空间与目标域标记空间之间的关系有所差异,在部分域适应问题中目标域的标记空间是源域标记空间的子集,在此场景下消除源域不相关类样本所产生的负迁移现象是解决部分域适应问题关键性的挑战.本文调查并回顾总结了近 5 年来绝大多数部分域适应问题的研究进展,并对目前针对部分域适应问题的解决方法进行了分类,其包括以促进正迁移为主的部分域适应方法以及抑制负迁移的部分域适应方法,尽管大部分工作在两者之间都有涉及,但其解决问题的方式有所不同.本文提出的部分域适应问题的分类法为研究人员更好地理解 and 解决相应的问题提供了一个框架和大体思路,以及未来的研究挑战和方向.通过对现有问题和未来方向的讨论,总结了这些挑战,本文认为部分域适应问题作为一个新的研究方向将受到人们的广泛关注,尤其是在不同场景下的应用.

References:

- [1] Gretton A, Borgwardt KM, Rasch M, Schölkopf B, Smola AJ. A kernel method for the two-sample-problem. *Advances in Neural Information Processing Systems*, 2006, 19: 513–520.
- [2] Satpal S, Sarawagi S. Domain adaptation of conditional probability models via feature subsetting. In: *Proc. of the 11th European Conf. on Principles and Practice of Knowledge Discovery in Databases*. Warsaw: Springer, 2007. 224–235. [doi: [10.1007/978-3-540-74976-9_23](https://doi.org/10.1007/978-3-540-74976-9_23)]
- [3] Tian Q, Ma C, Zhang FY, Peng S, Xue H. Source-free unsupervised domain adaptation with sample transport learning. *Journal of Computer Science and Technology*, 2021, 36(3): 606–616. [doi: [10.1007/s11390-021-1106-5](https://doi.org/10.1007/s11390-021-1106-5)]
- [4] Cao M, Tian Q, Ma TH, Chen SC. Human facial attributes estimation: A survey. *Ruan Jian Xue Bao/Journal of Software*, 2019, 30(7):

- 2188–2207 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5837.htm> [doi: 10.13328/j.cnki.jos.005837]
- [5] Pan SJ, Yang Q. A survey on transfer learning. *IEEE Trans. on Knowledge and Data Engineering*, 2010, 22(10): 1345–1359. [doi: 10.1109/TKDE.2009.191]
- [6] Pan SJ, Tsang IW, Kwok JT, Yang Q. Domain adaptation via transfer component analysis. *IEEE Trans. on Neural Networks*, 2011, 22(2): 199–210. [doi: 10.1109/TNN.2010.2091281]
- [7] Cao Y, Long MS, Wang JM. Unsupervised domain adaptation with distribution matching machines. In: *Proc. of the 32nd AAAI Conf. on Artificial Intelligence and the 30th Innovative Applications of Artificial Intelligence Conf. and the 8th AAAI Symp. on Educational Advances in Artificial Intelligence*. New Orleans: AAAI Press, 2018. 2795–2802.
- [8] Bousmalis K, Silberman N, Dohan D, Erhan D, Krishnan D. Unsupervised pixel-level domain adaptation with generative adversarial networks. In: *Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017. 95–104. [doi: 10.1109/CVPR.2017.18]
- [9] Chen C, Dou Q, Chen H, Heng PA. Semantic-aware generative adversarial nets for unsupervised domain adaptation in chest X-ray segmentation. In: *Proc. of the 9th Int'l Workshop on Machine Learning in Medical Imaging*. Granada: Springer, 2018. 143–151. [doi: 10.1007/978-3-030-00919-9_17]
- [10] Zhang Y, Miao S, Mansi T, Liao R. Task driven generative modeling for unsupervised domain adaptation: Application to X-ray image segmentation. In: *Proc. of the 21st Int'l Conf. on Medical Image Computing and Computer Assisted Intervention*. Granada: Springer, 2018. 599–607. [doi: 10.1007/978-3-030-00934-2_67]
- [11] Chen YH, Li W, Sakaridis C, Dai DX, van Gool L. Domain adaptive Faster R-CNN for object detection in the wild. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 3339–3348. [doi: 10.1109/CVPR.2018.00352]
- [12] Zhang Y, Barzilay R, Jaakkola T. Aspect-augmented adversarial networks for domain adaptation. *Trans. of the Association for Computational Linguistics*, 2017, 5: 515–528. [doi: 10.1162/tacl_a_00077]
- [13] Liu K, Zhao J. Domain adaptation in NLP based on hybrid generative and discriminative model. In: *Proc. of the 2008 Chinese Conf. on Pattern Recognition*. Beijing: IEEE, 2008. 1–6. [doi: 10.1109/CCPR.2008.11]
- [14] Li D, Huang JB, Li YL, Wang SJ, Yang MH. Weakly supervised object localization with progressive domain adaptation. In: *Proc. of the 2016 IEEE Conf. on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. 3512–3520. [doi: 10.1109/CVPR.2016.382]
- [15] Jiang J, Zhai CX. Instance weighting for domain adaptation in NLP. In: *Proc. of the 45th Annual Meeting of the Association of Computational Linguistics*. Prague: Association for Computational Linguistics, 2007. 264–271.
- [16] Inoue N, Furuta R, Yamasaki T, Aizawa K. Cross-domain weakly-supervised object detection through progressive domain adaptation. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 5001–5009. [doi: 10.1109/CVPR.2018.00525]
- [17] Bak S, Carr P, Lalonde JF. Domain adaptation through synthesis for unsupervised person re-identification. In: *Proc. of the 15th European Conf. on Computer Vision*. Munich: Springer, 2018. 193–209. [doi: 10.1007/978-3-030-01261-8_12]
- [18] Liu J, Zhang L. Optimal projection guided transfer hashing for image retrieval. *Proc. of the 2019 AAAI Conf. on Artificial Intelligence*, 2019, 33(1): 8754–8761. [doi: 10.1609/aaai.v33i01.33018754]
- [19] Deng WJ, Zheng L, Ye QX, Kang GL, Yang Y, Jiao JB. Image-image domain adaptation with preserved self-similarity and domain-dissimilarity for person re-identification. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 994–1003. [doi: 10.1109/CVPR.2018.00110]
- [20] Li HF, Chen YW, Tao DP, Yu ZT, Qi GQ. Attribute-aligned domain-invariant feature learning for unsupervised domain adaptation person re-identification. *IEEE Trans. on Information Forensics and Security*, 2020, 16: 1480–1494. [doi: 10.1109/TIFS.2020.3036800]
- [21] Li YJ, Yang FE, Liu YC, Yeh YY, Du XF, Wang YCF. Adaptation and re-identification network: An unsupervised deep transfer learning approach to person re-identification. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition Workshops*. Salt Lake City: IEEE, 2018. 285–291. [doi: 10.1109/CVPRW.2018.00054]
- [22] Wei LH, Zhang SL, Gao W, Tian Q. Person transfer GAN to bridge domain gap for person re-identification. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 79–88. [doi: 10.1109/CVPR.2018.00016]
- [23] Zhong Z, Zheng L, Luo ZM, Li SZ, Yang Y. Invariance matters: Exemplar memory for domain adaptive person re-identification. In: *Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Long Beach: IEEE, 2019. 598–607. [doi: 10.1109/CVPR.2019.00069]
- [24] Zhong Z, Zheng L, Zheng ZD, Li SZ, Yang Y. Camera style adaptation for person re-identification. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 5157–5166. [doi: 10.1109/CVPR.2018.00541]

- [25] Qi GJ, Aggarwal C, Tian Q, Ji H, Huang T. Exploring context and content links in social media: A latent space method. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2012, 34(5): 850–862. [doi: [10.1109/TPAMI.2011.191](https://doi.org/10.1109/TPAMI.2011.191)]
- [26] Zhang XH, Zhou Y, Zhao JQ, Zhang D, Yao R, Liu B. Entropy enhanced unsupervised domain adaptive remote sensing image semantic segmentation. *Application Research of Computers*, 2021, 38(9): 2852–2856 (in Chinese with English abstract). [doi: [10.19734/j.issn.1001-3695.2020.11.0431](https://doi.org/10.19734/j.issn.1001-3695.2020.11.0431)]
- [27] Guo H, Pasunuru R, Bansal M. Multi-source domain adaptation for text classification via distancenet-bandits. *Proc. of the 2020 AAAI Conf. on Artificial Intelligence*, 2020, 34(5): 7830–7838. [doi: [10.1609/aaai.v34i05.6288](https://doi.org/10.1609/aaai.v34i05.6288)]
- [28] Britz D, Le Q, Pryzant R. Effective domain mixing for neural machine translation. In: *Proc. of the 2nd Conf. on Machine Translation*. Copenhagen: Association for Computational Linguistics, 2017. 118–126. [doi: [10.18653/v1/W17-4712](https://doi.org/10.18653/v1/W17-4712)]
- [29] Wang R, Utiyama M, Finch A, Liu LM, Chen KH, Sumita E. Sentence selection and weighting for neural machine translation domain adaptation. *IEEE/ACM Trans. on Audio, Speech, and Language Processing*, 2018, 26(10): 1727–1741. [doi: [10.1109/TASLP.2018.2837223](https://doi.org/10.1109/TASLP.2018.2837223)]
- [30] Chu CH, Dabre R, Kurohashi S. A comprehensive empirical comparison of domain adaptation methods for neural machine translation. *Journal of Information Processing*, 2018, 26: 529–538. [doi: [10.2197/ipsjip.26.529](https://doi.org/10.2197/ipsjip.26.529)]
- [31] Yang ZL, Hu JJ, Salakhutdinov R, Cohen WW. Semi-supervised QA with generative domain-adaptive nets. arXiv:1702.02206, 2017.
- [32] Cao ZJ, Long MS, Wang JM, Jordan MI. Partial transfer learning with selective adversarial networks. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 2724–2732. [doi: [10.1109/CVPR.2018.00288](https://doi.org/10.1109/CVPR.2018.00288)]
- [33] He NY, Zhu J. A weighted partial domain adaptation for acoustic scene classification and its application in fiber optic security system. *IEEE Access*, 2021, 9: 2244–2250. [doi: [10.1109/ACCESS.2020.3044153](https://doi.org/10.1109/ACCESS.2020.3044153)]
- [34] Tian YJ, Zhu SY. Partial domain adaptation on semantic segmentation. *IEEE Trans. on Circuits and Systems for Video Technology*, 2022, 32(6): 3798–3809. [doi: [10.1109/TCSVT.2021.3116210](https://doi.org/10.1109/TCSVT.2021.3116210)]
- [35] Gretton A, Borgwardt KM, Rasch MJ, Schölkopf B, Smola A. A kernel two-sample test. *The Journal of Machine Learning Research*, 2012, 13: 723–773.
- [36] Dorri F, Ghodsi A. Adapting component analysis. In: *Proc. of the 12th IEEE Int'l Conf. on Data Mining*. Brussels: IEEE, 2012. 846–851. [doi: [10.1109/ICDM.2012.85](https://doi.org/10.1109/ICDM.2012.85)]
- [37] Duan LX, Tsang IW, Xu D. Domain transfer multiple kernel learning. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2012, 34(3): 465–479. [doi: [10.1109/TPAMI.2011.114](https://doi.org/10.1109/TPAMI.2011.114)]
- [38] Kulpa W. Poincaré and domain invariance theorem. *Acta Universitatis Carolinae—Mathematica et Physica*, 1998, 39(1–2): 127–136.
- [39] Long MS, Cao Y, Wang JM, Jordan MI. Learning transferable features with deep adaptation networks. In: *Proc. of the 32nd Int'l Conf. on Machine Learning*. Lille: JMLR.org, 2015. 97–105.
- [40] Baktashmotlagh M, Harandi M, Salzman M. Distribution-matching embedding for visual domain adaptation. *The Journal of Machine Learning Research*, 2016, 17(1): 3760–3789.
- [41] Zhang K, Schölkopf B, Muandet K, Wang ZK. Domain adaptation under target and conditional shift. In: *Proc. of the 30th Int'l Conf. on Machine Learning*. Atlanta: JMLR.org, 2013. 819–827.
- [42] Gong MM, Zhang K, Liu TL, Tao DC, Glymour C, Schölkopf B. Domain adaptation with conditional transferable components. In: *Proc. of the 33rd Int'l Conf. on Machine Learning*. New York: JMLR.org, 2016. 2839–2848.
- [43] Long MS, Cao ZJ, Wang JM, Jordan MI. Conditional adversarial domain adaptation. In: *Proc. of the 32nd Int'l Conf. on Neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018. 1647–1657.
- [44] Cao K, Tu ZP, Ming Y. Class conditional distribution alignment for domain adaptation. *Control Theory and Technology*, 2020, 18(1): 72–80. [doi: [10.1007/s11768-020-9126-1](https://doi.org/10.1007/s11768-020-9126-1)]
- [45] Long MS, Wang JM, Ding GG, Sun JG, Yu PS. Transfer feature learning with joint distribution adaptation. In: *Proc. of the 2013 IEEE Int'l Conf. on Computer Vision*. Sydney: IEEE, 2013. 2200–2207. [doi: [10.1109/ICCV.2013.274](https://doi.org/10.1109/ICCV.2013.274)]
- [46] Zhang J, Li WQ, Ogunbona P. Joint geometrical and statistical alignment for visual domain adaptation. In: *Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017. 5150–5158. [doi: [10.1109/CVPR.2017.547](https://doi.org/10.1109/CVPR.2017.547)]
- [47] Long MS, Zhu H, Wang JM, Jordan MI. Deep transfer learning with joint adaptation networks. In: *Proc. of the 34th Int'l Conf. on Machine Learning*. Sydney: JMLR.org, 2017. 2208–2217.
- [48] Wang JD, Chen YQ, Hao SJ, Feng WJ, Shen ZQ. Balanced distribution adaptation for transfer learning. In: *Proc. of the 2017 IEEE Int'l Conf. on Data Mining*. New Orleans: IEEE, 2017. 1129–1134. [doi: [10.1109/ICDM.2017.150](https://doi.org/10.1109/ICDM.2017.150)]
- [49] Li JJ, Jing MM, Lu K, Zhu L, Shen HT. Locality preserving joint transfer for domain adaptation. *IEEE Trans. on Image Processing*, 2019, 28(12): 6103–6115. [doi: [10.1109/TIP.2019.2924174](https://doi.org/10.1109/TIP.2019.2924174)]


- [50] Borgwardt KM, Gretton A, Rasch MJ, Kriegel HP, Schölkopf B, Smola AJ. Integrating structured biological data by kernel maximum mean discrepancy. *Bioinformatics*, 2006, 22(14): e49–e57. [doi: [10.1093/bioinformatics/btl242](https://doi.org/10.1093/bioinformatics/btl242)]
- [51] Long MS, Wang JM, Ding GG, Pan SJ, Yu PS. Adaptation regularization: A general framework for transfer learning. *IEEE Trans. on Knowledge and Data Engineering*, 2014, 26(5): 1076–1089. [doi: [10.1109/TKDE.2013.111](https://doi.org/10.1109/TKDE.2013.111)]
- [52] Jing TT, Ming S, Ding ZM. Discriminative cross-domain feature learning for partial domain adaptation. arXiv:2008.11360, 2020.
- [53] Long MS, Zhu H, Wang JM, Jordan MI. Unsupervised domain adaptation with residual transfer networks. In: *Proc. of the 30th Int'l Conf. on Neural Information Processing Systems*. Barcelona: Curran Associates Inc., 2016. 136–144.
- [54] Long MS, Wang JM, Ding GG, Sun JG, Yu PS. Transfer joint matching for unsupervised domain adaptation. In: *Proc. of the 2014 IEEE Conf. on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014. 1410–1417. [doi: [10.1109/CVPR.2014.183](https://doi.org/10.1109/CVPR.2014.183)]
- [55] Volpi R, Morerio P, Savarese S, Murino V. Adversarial feature augmentation for unsupervised domain adaptation. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 5495–5504. [doi: [10.1109/CVPR.2018.00576](https://doi.org/10.1109/CVPR.2018.00576)]
- [56] Li WK, Chen SC. Partial domain adaptation without domain alignment. arXiv:2108.12867, 2021.
- [57] Kheirandishfard M, Zohrizadeh F, Kamangar F. Class conditional alignment for partial domain adaptation. In: *Proc. of the 25th Int'l Conf. on Pattern Recognition*. Milan: IEEE, 2021. 811–818. [doi: [10.1109/ICPR48806.2021.9412457](https://doi.org/10.1109/ICPR48806.2021.9412457)]
- [58] Ramachandran P, Parmar N, Vaswani A, Bello I, Levskaya A, Shlens J. Stand-alone self-attention in vision models. In: *Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems*. Vancouver, 2019. 68–80.
- [59] Xie SN, Liu SN, Chen ZY, Tu ZW. Attentional ShapeContextNet for point cloud recognition. In: *Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018. 4606–4615. [doi: [10.1109/CVPR.2018.00484](https://doi.org/10.1109/CVPR.2018.00484)]
- [60] Cao ZZ, Wang R, Wang XY, Liu Z, Zhu XQ. Improving human pose estimation with self-attention generative adversarial networks. In: *Proc. of the 2019 IEEE Int'l Conf. on Multimedia and Expo Workshops*. Shanghai: IEEE, 2019. 567–572. [doi: [10.1109/ICMEW.2019.00103](https://doi.org/10.1109/ICMEW.2019.00103)]
- [61] Chu X, Yang W, Ouyang WL, Ma C, Yuille AL, Wang XG. Multi-context attention for human pose estimation. In: *Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017. 5669–5678. [doi: [10.1109/CVPR.2017.601](https://doi.org/10.1109/CVPR.2017.601)]
- [62] Tzeng E, Hoffman J, Zhang N, Saenko K, Darrell T. Deep domain confusion: Maximizing for domain invariance. arXiv:1412.3474, 2014.
- [63] Yu AW, Dohan D, Luong D, Zhao R, Chen K, Norouzi M, Le QC. QANet: Combining local convolution with global self-attention for reading comprehension. arXiv:1804.09541, 2018.
- [64] Zhang B, Xiong DY, Xie J, Su JS. Neural machine translation with GRU-gated attention model. *IEEE Trans. on Neural Networks and Learning Systems*, 2020, 31(11): 4688–4698. [doi: [10.1109/TNNLS.2019.2957276](https://doi.org/10.1109/TNNLS.2019.2957276)]
- [65] Ma QX, Song JY, Zhang T. Positional self-attention based hierarchical image captioning. In: *Proc. of the 2019 IEEE Int'l Conf. on Robotics and Biomimetics*. Dali: IEEE, 2019. 1173–1178. [doi: [10.1109/ROBIO49542.2019.8961665](https://doi.org/10.1109/ROBIO49542.2019.8961665)]
- [66] Vinyals O, Toshev A, Bengio S, Erhan D. Show and tell: A neural image caption generator. In: *Proc. of the 2015 IEEE Conf. on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015. 3156–3164. [doi: [10.1109/CVPR.2015.7298935](https://doi.org/10.1109/CVPR.2015.7298935)]
- [67] Zhang CC, Zhao QJ. Attention guided for partial domain adaptation. *Information Sciences*, 2021, 547: 860–869. [doi: [10.1016/j.ins.2020.08.103](https://doi.org/10.1016/j.ins.2020.08.103)]
- [68] Huang JC, Zhang PY, Zhou ZH, Fan KF. Domain compensatory adversarial networks for partial domain adaptation. *Multimedia Tools and Applications*, 2021, 80(7): 11255–11272. [doi: [10.1007/s11042-020-10193-0](https://doi.org/10.1007/s11042-020-10193-0)]
- [69] Bronstein MM, Bruna J, Lecun Y, Szlam A, Vandergheynst P. Geometric deep learning: Going beyond Euclidean data. *IEEE Signal Processing Magazine*, 2017, 34(4): 18–42. [doi: [10.1109/MSP.2017.2693418](https://doi.org/10.1109/MSP.2017.2693418)]
- [70] Hamilton WL, Ying R, Leskovec J. Representation learning on graphs: Methods and applications. arXiv:1709.05584, 2018.
- [71] Kipf TN, Wainwright M. Semi-supervised classification with graph convolutional networks. arXiv:1609.02907, 2017.
- [72] Ding ZM, Li S, Shao M, Fu Y. Graph adaptive knowledge transfer for unsupervised domain adaptation. In: *Proc. of the 15th European Conf. on Computer Vision*. Munich: Springer, 2018. 36–52. [doi: [10.1007/978-3-030-01216-8_3](https://doi.org/10.1007/978-3-030-01216-8_3)]
- [73] Kim Y, Hong S, Yang S, Kang S, Jeon Y, Kim J. Associative partial domain adaptation. arXiv:2008.03111, 2020.
- [74] Gori M, Monfardini G, Scarselli F. A new model for learning in graph domains. In: *Proc. of the 2015 IEEE Int'l Joint Conf. on Neural Networks*. Montreal: IEEE, 2005. 729–734. [doi: [10.1109/IJCNN.2005.1555942](https://doi.org/10.1109/IJCNN.2005.1555942)]
- [75] Scarselli F, Gori M, Tsoi AC, Hagenbuchner M, Monfardini G. The graph neural network model. *IEEE Trans. on Neural Networks*, 2009, 20(1): 61–80. [doi: [10.1109/TNN.2008.2005605](https://doi.org/10.1109/TNN.2008.2005605)]
- [76] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. In: *Proc. of the 25th Int'l*

- Conf. on Neural Information Processing Systems. Lake Tahoe: Curran Associates Inc., 2012. 1097–1105.
- [77] Ma XH, Zhang TZ, Xu CS. GCAN: Graph convolutional adversarial network for unsupervised domain adaptation. In: Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 8258–8268. [doi: [10.1109/CVPR.2019.00846](https://doi.org/10.1109/CVPR.2019.00846)]
- [78] Yang SH, Kim Y, Jung D, Kim C. Partial domain adaptation using graph convolutional networks. arXiv:2005.07858, 2020.
- [79] Kim Y, Hong S. Adaptive graph adversarial networks for partial domain adaptation. IEEE Trans. on Circuits and Systems for Video Technology, 2022, 32(1): 172–182. [doi: [10.1109/TCSVT.2021.3056208](https://doi.org/10.1109/TCSVT.2021.3056208)]
- [80] Chen ZH, Chen C, Cheng ZW, Jiang BY, Fang K, Jin XY. Selective transfer with reinforced transfer network for partial domain adaptation. In: Proc. of the 2020 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 12703–12711. [doi: [10.1109/CVPR42600.2020.01272](https://doi.org/10.1109/CVPR42600.2020.01272)]
- [81] Chen J, Wu XX, Duan LX, Gao SH. Domain adversarial reinforcement learning for partial domain adaptation. IEEE Trans. on Neural Networks and Learning Systems, 2022, 33(2): 539–553. [doi: [10.1109/TNNLS.2020.3028078](https://doi.org/10.1109/TNNLS.2020.3028078)]
- [82] Li LS, Wan ZQ, He HB. Dual alignment for partial domain adaptation. IEEE Trans. on Cybernetics, 2021, 51(7): 3404–3416. [doi: [10.1109/TCYB.2020.2983337](https://doi.org/10.1109/TCYB.2020.2983337)]
- [83] Ren CX, Ge PF, Yang PY, Yan SC. Learning target-domain-specific classifier for partial domain adaptation. IEEE Trans. on Neural Networks and Learning Systems, 2021, 32(5): 1989–2001. [doi: [10.1109/TNNLS.2020.2995648](https://doi.org/10.1109/TNNLS.2020.2995648)]
- [84] Jing TT, Xia HF, Ding ZM. Adaptively-accumulated knowledge transfer for partial domain adaptation. In: Proc. of the 28th ACM Int'l Conf. on Multimedia. Seattle: Association for Computing Machinery, 2020. 1606–1614. [doi: [10.1145/3394171.3413986](https://doi.org/10.1145/3394171.3413986)]
- [85] Wang Q, Toby PB. Source class selection with label propagation for partial domain adaptation. In: Proc. of the 2021 IEEE Int'l Conf. on Image Processing. Anchorage: IEEE, 2021. 769–773. [doi: [10.1109/ICIP42928.2021.9506752](https://doi.org/10.1109/ICIP42928.2021.9506752)]
- [86] Zhang YB, Deng B, Jia K, Zhang L. Label propagation with augmented anchors: A simple semi-supervised learning baseline for unsupervised domain adaptation. In: Proc. of the 16th European Conf. on Computer Vision. Glasgow: Springer, 2020. 781–797. [doi: [10.1007/978-3-030-58548-8_45](https://doi.org/10.1007/978-3-030-58548-8_45)]
- [87] Ahmed W, Morerio P, Murino V. Adaptive pseudo-label refinement by negative ensemble learning for source-free unsupervised domain adaptation. arXiv:2103.15973, 2021.
- [88] Li S, Gong KX, Xie BH, Liu CH, Cao WP, Tian S. Critical classes and samples discovering for partial domain adaptation. IEEE Trans. on Cybernetics, 2023, 53(9): 5641–5654. [doi: [10.1109/TCYB.2022.3163432](https://doi.org/10.1109/TCYB.2022.3163432)]
- [89] Zohrizadeh F, Kheirandishfard M, Kamangar F. Class subset selection for partial domain adaptation. In: Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 66–72.
- [90] Choudhuri S, Paul R, Sen A, Li BX, Venkateswara H. Partial domain adaptation using selective representation learning for class-weight computation. In: Proc. of the 54th Asilomar Conf. on Signals, Systems, and Computers. Pacific Grove: IEEE, 2020. 289–293. [doi: [10.1109/IEEECONF51394.2020.9443420](https://doi.org/10.1109/IEEECONF51394.2020.9443420)]
- [91] Sahoo A, Panda R, Feris R, Saenko K, Das A. Select, label, and mix: Learning discriminative invariant feature representations for partial domain adaptation. arXiv:2012.03358, 2020.
- [92] Bucci S, D'Innocente A, Tommasi T. Tackling partial domain adaptation with self-supervision. In: Proc. of the 20th Int'l Conf. on Image Analysis and Processing. Trento: Springer, 2019. 70–81. [doi: [10.1007/978-3-030-30645-8_7](https://doi.org/10.1007/978-3-030-30645-8_7)]
- [93] Liang J, Wang YB, Hu DP, He R, Feng JS. A balanced and uncertainty-aware approach for partial domain adaptation. In: Proc. of the 16th European Conf. on Computer Vision. Glasgow: Springer, 2020. 123–140. [doi: [10.1007/978-3-030-58621-8_8](https://doi.org/10.1007/978-3-030-58621-8_8)]
- [94] Cao ZJ, Ma LJ, Long MS, Wang JM. Partial adversarial domain adaptation. In: Proc. of the 15th European Conf. on Computer Vision. Munich: Springer, 2018. 139–155. [doi: [10.1007/978-3-030-01237-3_9](https://doi.org/10.1007/978-3-030-01237-3_9)]
- [95] Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, Marchand M, Lempitsky V. Domain-adversarial training of neural networks. The Journal of Machine Learning Research, 2016, 17(1): 2096–2030.
- [96] Cao ZJ, You KC, Long MS, Wang JM, Yang Q. Learning to transfer examples for partial domain adaptation. In: Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 2980–2989. [doi: [10.1109/CVPR.2019.00310](https://doi.org/10.1109/CVPR.2019.00310)]
- [97] Zhang J, Ding ZW, Li WQ, Ogunbona P. Importance weighted adversarial nets for partial domain adaptation. In: Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 8156–8164. [doi: [10.1109/CVPR.2018.00851](https://doi.org/10.1109/CVPR.2018.00851)]
- [98] Cao XF, Yang J, Meng XB. Partial domain adaptation for relation extraction based on adversarial learning. In: Proc. of the 17th Int'l Conf. on the Semantic Web. Heraklion: Springer, 2020. 89–104. [doi: [10.1007/978-3-030-49461-2_6](https://doi.org/10.1007/978-3-030-49461-2_6)]
- [99] Qiu WJ, Chen WD, Hu HF. Partial domain adaptation based on shared class oriented adversarial network. Computer Vision and Image Understanding, 2020, 199: 103018. [doi: [10.1016/j.cviu.2020.103018](https://doi.org/10.1016/j.cviu.2020.103018)]

- [100] Hu J, Zhong HW, Tuo HY, Jing ZL, Wang C. Multi-weight partial domain adaptation. In: Proc. of the 2019 British Machine Vision Conf. Cardiff: BMVC, 2019. 1–11.
- [101] Yang CE, Cheung YM, Ding JL, Tan KC, Xue B, Zhang MJ. Contrastive learning assisted-alignment for partial domain adaptation. IEEE Trans. on Neural Networks and Learning Systems, 2023, 34(10): 7621–7634. [doi: 10.1109/TNNLS.2022.3145034]
- [102] Matsuura T, Saito K, Harada T. TWINS: Two weighted inconsistency-reduced networks for partial domain adaptation. arXiv: 1812.07405, 2018.
- [103] Saenko K, Kulis B, Fritz M, Darrell T. Adapting visual category models to new domains. In: Proc. of the 11th European Conf. on Computer Vision. Heraklion: Springer, 2010. 213–226. [doi: 10.1007/978-3-642-15561-1_16]
- [104] Gong BQ, Shi Y, Sha F, Grauman K. Geodesic flow kernel for unsupervised domain adaptation. In: Proc. of the 2012 IEEE Conf. on Computer Vision and Pattern Recognition. Providence: IEEE, 2012. 2066–2073. [doi: 10.1109/CVPR.2012.6247911]
- [105] Zhang L, Zuo WM, Zhang D. LSDT: Latent sparse domain transfer learning for visual adaptation. IEEE Trans. on Image Processing, 2016, 25(3): 1177–1191. [doi: 10.1109/TIP.2016.2516952]
- [106] Stallkamp J, Schlipsing M, Salmen J, Igel C. The German traffic sign recognition benchmark: A multi-class classification competition. In: Proc. of the 2011 Int'l Joint Conf. on Neural Networks. San Jose: IEEE, 2011. 1453–1460. [doi: 10.1109/IJCNN.2011.6033395]
- [107] Venkateswara H, Eusebio J, Chakraborty S, Panchanathan S. Deep hashing network for unsupervised domain adaptation. In: Proc. of the 2017 IEEE Conf. on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 5385–5394. [doi: 10.1109/CVPR.2017.572]
- [108] Caputo B, Müller H, Martínez-Gómez J, Villegas M, Acar B, Patricia N, Marvasti N, Üsküdarlı S, Paredes R, Cazorla M, Garcia-Varea I, Morell V. ImageCLEF 2014: Overview and analysis of the results. In: Proc. of the 5th Int'l Conf. of the CLEF Initiative. Sheffield: Springer, 2014. 192–211. [doi: 10.1007/978-3-319-11382-1_18]
- [109] Li S, Liu CH, Lin QX, Wen Q, Su LM, Huang G, Ding ZM. Deep residual correction network for partial domain adaptation. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2021, 43(7): 2329–2344. [doi: 10.1109/TPAMI.2020.2964173]
- [110] Tian Q, Sun HY, Ma C, Cao M, Chu Y, Chen SC. Heterogeneous domain adaptation with structure and classification space alignment. IEEE Trans. on Cybernetics, 2022, 52(10): 10328–10338. [doi: 10.1109/TCYB.2021.3070545]

附中文参考文献:

- [4] 曹猛, 田青, 马廷淮, 陈松灿. 人类面部属性估计研究: 综述. 软件学报, 2019, 30(7): 2188–2207. <http://www.jos.org.cn/1000-9825/5837.htm> [doi: 10.13328/j.cnki.jos.005837]
- [26] 张勋晖, 周勇, 赵佳琦, 张迪, 姚睿, 刘兵. 基于熵增强的无监督域适应遥感图像语义分割. 计算机应用研究, 2021, 38(9): 2852–2856. [doi: 10.19734/j.issn.1001-3695.2020.11.0431]



田青(1984—), 男, 博士, 副教授, CCF 高级会员, 主要研究领域为机器学习, 模式识别.



吴一昕(1999—), 男, 硕士生, 主要研究领域为机器学习, 模式识别.



储奕(1997—), 男, 硕士生, 主要研究领域为机器学习, 模式识别.



陈松灿(1962—) 男, 博士, 教授, CCF 高级会员, 主要研究领域为机器学习, 模式识别.



孙赫阳(1995—), 男, 硕士生, 主要研究领域为机器学习, 模式识别.